

# Methoden zur KI-basierten Autovervollständigung von frühen Grundrissentwürfen: Methodologie und Integration in ein bestehendes Framework

V. Eisenstadt<sup>1,2</sup>, J. Bielski<sup>3</sup>, C. Langenhan<sup>3</sup>, B. Mete<sup>3</sup>, K.-D. Althoff<sup>1,2</sup> and A. Dengel<sup>1</sup>

<sup>1</sup>Deutsches Forschungszentrum für Künstliche Intelligenz (DFKI), Deutschland

<sup>2</sup>Universität Hildesheim, Institut für Informatik, Deutschland

<sup>3</sup>Technische Universität München, Dept. Architektur, Deutschland

E-mail(s): viktor.eisenstadt@dfki.de

**Abstract:** Der Prozess des Entwerfens in der Architektur verbindet die Kreativität des Designers mit gesetzlichen Regularien sowie den spezifischen Einschränkungen und Vorgaben des Bauprojektes. Der Entwurfsprozess ist somit eine geeignete Domäne für die Unterstützung durch den Computer, welcher die Aufgabe eines Assistenten übernimmt und das Projekt getreu der Vorgaben ko-kreativ begleitet. Die Methoden der Künstlichen Intelligenz (KI), insbesondere Deep Learning, haben in der letzten Zeit große Fortschritte gemacht, in der Unterstützung des Entwurfsprozesses in der Architektur spielen sie zur Zeit jedoch noch eine untergeordnete Rolle. Ein möglicher Einsatz der KI-Techniken im Entwurfsprozess von der Architektur ist die automatische Vervollständigung der Grundrisse in den frühen Entwurfsphasen. Die von der KI generierten Vorschläge für die nächsten Entwurfsschritte basieren dabei auf vorhandenen konsistenten semantischen Daten und tragen so zu mehr Präzision sowie Effizienz im Entwurfsprozess bei. Wir präsentieren eine Methodologie für eine solche Autovervollständigung und beschreiben wie sie in ein bestehendes verteiltes KI-basiertes Framework integriert wird und wie die generierten Vorschläge dem Nutzer erklärt werden.

*Keywords:* Frühe Entwurfsphasen, Raumkonfiguration, Autovervollständigung, Deep Learning

## 1 Einführung

In den letzten Dekaden verzeichnet Künstliche Intelligenz (KI) einen kontinuierlichen Zuwachs an neuen Methoden und Techniken. Insbesondere Deep Learning (DL) erfreut sich einer stetig wachsenden Anwendung. Neueste Entwicklungen wie Generative Adversarial Nets [1] oder GPT-3 (Generative Pre-trained Transformer) [2] werden als wichtige Fortschritte der aktuellen KI-Forschung betrachtet.

In der Architektur ist die Anwendung der genannten KI-Methoden jedoch noch nicht etabliert. Die Forschungsprojekte *metis-I* und *metis-II*, gefördert durch Deutsche Forschungsgemeinschaft (DFG), untersuchen das Potential der KI-Methoden für die frühen Phasen des Entwurfsprozesses in der Architektur. Angefangen mit der fallbasierten Suche nach ähnlichen Entwürfen, wurden die Forschungsaktivitäten mit den Methoden zur synthetischen Generierung von hochwertigen Entwürfen fortgesetzt. Aktuell beschäftigen sich die Projekte mit der Autovervollständigung von graphbasierten Raumkonfigurationen mithilfe von DL, um die frühen Designphasen in der Architektur effizienter und ressourcenschonender zu gestalten und damit die allgemeine Qualität des frühen Entwurfs zu erhöhen [3]. Die Effizienz und die Ergebnisqualität der frühen Designentscheidungen beeinflussen den weiteren Verlauf des Entwurfsprozesses [4, S. 10]. Es ist also von besonderer Bedeutung auf die Methoden zu setzen, die in der Lage sind große Datenmengen effizient und zuverlässig zu verarbeiten und die Ergebnisse der vorherigen Aktionen für die nächsten Handlungsempfehlungen (und die möglichen Alternativen) zu berücksichtigen. Deep Learning hat sich dabei als eine geeignete Grundlage bewiesen, bspw. bei der Autokorrektur der Sätze auf dem Smartphone oder Früherkennung der Börsentrends.

In diesem Beitrag stellen wir eine Methodologie der DL-basierten Autovervollständigung von frühen Grundrissentwürfen vor, mit einem besonderen Fokus auf dem Zusammenspiel der beteiligten Algorithmen und Datenstrukturen. Zum Einsatz kommen die Methoden wie die künstlichen Neuronen Netze, Clustering, Link Prediction und Multiagentensysteme. Ein besonderer Schwerpunkt ist das (selbst-)erklärende Handeln des Systems, welches mithilfe der Anwendung von eXplainable AI (XAI) erreicht werden soll. Die Methodologie wird dabei als ein ganzheitlicher Prozess gesehen, der die Architekten sowohl auf der Suche nach den nächsten Designentscheidungen begleiten soll als auch in der Lage ist den aktuellen Status des Entwurfs zu ermitteln, um fehlende Elemente oder Korrekturen für die aktuelle Entwurfsaufgabe vorzuschlagen. Die Vorschläge zur Vervollständigung basieren dabei auf den Erfahrungen des aktuellen Nutzers (Personalisierung), aber auch auf den Aufzeichnungen der Entwurfsprozesse anderer Architekten und den Referenz-Entwürfen bereits gebauter Projekte. Abgeschlossen wird der Beitrag mit einem Ausblick auf die weiteren Perspektiven der Methodologie.

## 2 Grundlagen der Methodologie

Die Grundlagen der KI-basierten Vervollständigung der frühen Grundrissentwürfe können grob in die technischen Voraussetzungen sowie die Rahmenbedingungen innerhalb des Entwurfsprozesses unterteilt werden. Technisch sind vor allem die richtige Repräsentation der Semantik der Grundrissdaten sowie die passenden Methoden der KI notwendig. Der Einsatzrahmen dieser KI-Methoden ist die frühe Entwurfsphase, in der die einflussreichen Designentscheidungen getroffen werden (s. Kap. 1).

Gekennzeichnet ist die frühe Entwurfsphase vor allem durch die Vielfalt der (vagen) Ideen, die sowohl intern als auch extern diskutiert und evaluiert werden [4, S. 24]. Kommuniziert werden diese frühen Ideen in der Regel mithilfe von Skizzen, die eine Auswahl an Variationen des Konzeptes repräsentieren und so einen Ideenraum schaffen, der den weiteren Verlauf des Bauprojektes maßgeblich mitbestimmt. Laseau [5] betrachtet die Visualisierung der Ideen mithilfe von Skizzen als optimalen

Kommunikationsweg. HOAI (Honorarordnung für Architekten und Ingenieure) und AIA (American Institute of Architects) schätzen den Anteil der frühen Entwurfsphase auf ca. 30% der gesamten Entwurfszeit.

Während der frühen Entwurfsphase entstehen die Ideen im Wesentlichen mithilfe von Inspirationen durch die Inspektion der Referenzobjekte in Form von Abbildungen/3D-Modellen oder durch persönliche Besuche von Objekten [6, S. 143ff]. Digitale Methoden können die Suche nach Inspirationen beschleunigen und wurden im Forschungsprojekt *metis-I* untersucht. Eine weitere Möglichkeit der Unterstützung der frühen Ideenfindung durch den Computer ist die Erarbeitung einer oder mehrerer Alternativen zur Fortsetzung des Entwurfsprozesses basierend auf den Erfahrungen des Entwerfenden und anderer Architekten. KI-Methoden der Autovervollständigung erhalten oder erhöhen dabei die Qualität des Entwurfs, reduzieren den Arbeitsstress und beschleunigen die Entscheidungsfindung. Dies erhöht ebenfalls die Nachhaltigkeit durch Reduzierung von Bauschutt [7].

Die KI-kompatible Repräsentation des frühen Grundrisses erfolgt über die Interpretation der Semantik der Skizze als Graph in dem die Knoten für die Räume stehen (bspw. *Living*, *Working*, *Sleeping*) und die Kanten die Verbindungen zwischen den Räumen (bspw. *Door*, *Passage*) repräsentieren. Der Graph wird dabei als *Raumkonfiguration* bezeichnet (s. Abb. 1). Während für die Suche nach ähnlichen Referenzen der Graph selbst oder seine attribut-wert-basierte Repräsentation ausreichen, erfordert der Einsatz von Deep Learning andere Repräsentationsformen. Im Forschungsprojekt *metis-II* wurde zu diesem Zweck die tensor-basierte Repräsentation „Relation Map“ [8] entwickelt, die die Semantik der Raumkonfiguration in Form von One-Hot-Vektoren, numerischen Codes oder Texte darstellt. Dabei wird jeweils eine mehrdimensionale Matrix angelegt, die in dieser Form von den bekannten Deep-Learning-Softwarebibliotheken TensorFlow oder PyTorch interpretiert werden kann.

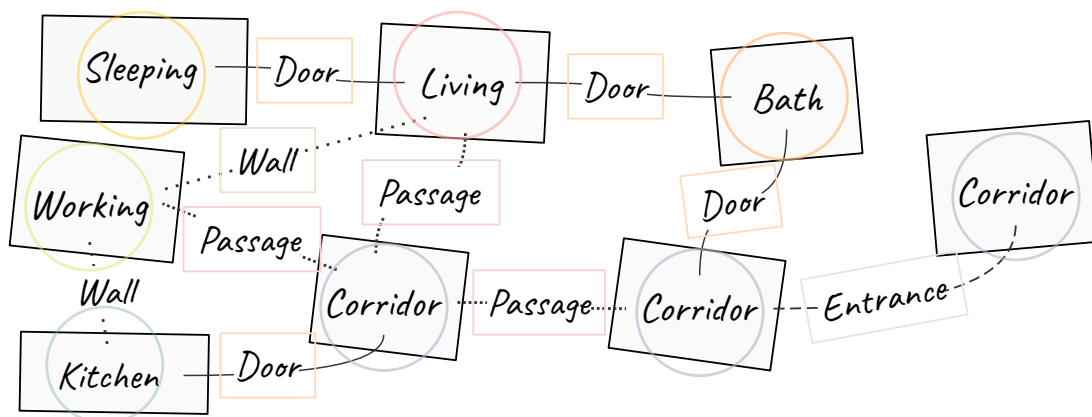


Abbildung 1: Grundrisskonfiguration interpretiert als Graph (Raumkonfiguration).

Ferner können die Daten des Entwurfsprozesses als eine Folge von ausgeführten Entwurfsschritten während der Skizzierung eines frühen Grundrisses repräsentiert werden. Diese können entweder als konkrete Aktionen (bspw. Raum oder Verbindung hinzufügen/entfernen) in einer Sequenz aufgezeichnet oder über die Angaben zur Position/Druckstärke/Zeitstempel des digitalen Stifts ermittelt werden. Beide Formen wurden bereits im Rahmen des Projektes *metis-II* in spezifischen Tools implementiert

und evaluiert. Erforderlich sind solche Daten unter anderem für die Erkennung der Phase in der sich der aktuelle Nutzer befindet. Im Projekt *metis-II* wird dabei auf die Erweiterung des Modells ASE [9] gesetzt, das zwischen den einzelnen Phasen *Analysis*, *Synthesis* und *Evaluation* unterscheidet.

### 3 Methodologie der Autovervollständigung

In diesem Kapitel wird die Methodologie der Autovervollständigung von Raumkonfigurationen vorgestellt. Basierend auf der Gesamtübersicht (s. Abb. 2) werden nachfolgend die detaillierten Beschreibungen der KI-Algorithmen, der Datenstrukturen und der Erklärungskomponente präsentiert.

#### 3.1 KI-Algorithmen & Datenstrukturen

Insgesamt werden bei der Methodologie zwei Ansätze verfolgt. Beide setzen auf eine überwiegend sequentielle Ausführung der beteiligten Methoden zur Generierung von einer oder mehreren Alternativen zur Fortsetzung des frühen Entwurfsprozesses, basierend auf dem aktuellen Stand des Entwurfs. Der aktuelle Stand (s. Abb. 2, oben) setzt sich zusammen aus den oben genannten Datenstrukturen Graph (Raumkonfiguration) sowie Textsequenz (bisherige Entwurfsschritte). Diese werden dann für den jeweiligen Ansatz als initiale Anfrage genutzt und im weiteren Verlauf modifiziert.

##### 3.1.1 Ansatz 1: ASE-Phase + Intention + Entwurfsschritt

Im ersten Schritt des ersten Ansatzes (s. Abb. 2, links) wird die aktuelle ASE-Phase des Nutzers ermittelt indem die Teilsequenz der bisherigen Entwurfsschritte von einem rekurrenten neuronalen Netz (engl.: recurrent neural network, RNN) ausgewertet wird. Die ASE-Phase beschreibt im wesentlichen die aktuelle Aktivität des Entwerfenden während der frühen Entwurfsphase gemäß dem ASE-Modell. Das RNN ist in der Lage sich an die Folge und Abhängigkeiten zwischen den Einträgen (hier: Entwurfsschritten) in einer Sequenz zu erinnern und ist daher die passende Wahl für diesen Ansatz. Als Ergebnis gibt das RNN die aktuelle Phase des Entwurfs zurück, basierend auf den Weiterentwicklungen des ASE-Modells (s. Kap. 2) durch Laseau [5] und Barelkowski [10]. Bspw. können die Phasen *Analysis-Understanding* (Festlegen der Entwurfsziele), *Synthesis-Discovery* (Lösungsfindung in einer der Entwurfsalternativen), oder *Evaluation* (Vergleich/Selektion der Lösungen) erkannt werden.

Ist die ASE-Phase erkannt, geht es mit dem zweiten Schritt weiter in dem die aktuelle Intention des Entwerfenden erkannt wird. Dies geschieht mithilfe eines weiteren RNNs auf Basis der Entwurfsschritte und der zuvor ermittelten ASE-Phase. Die Intention präzisiert dabei das aktuelle Vorhaben des Architekten, geteilt in Aspekte *wie* und *was* [9]. Bspw. können die Intentionen wie „requesting information“, „exploring different direction“ oder „modifying/adding/deleting solution“ erkannt werden.

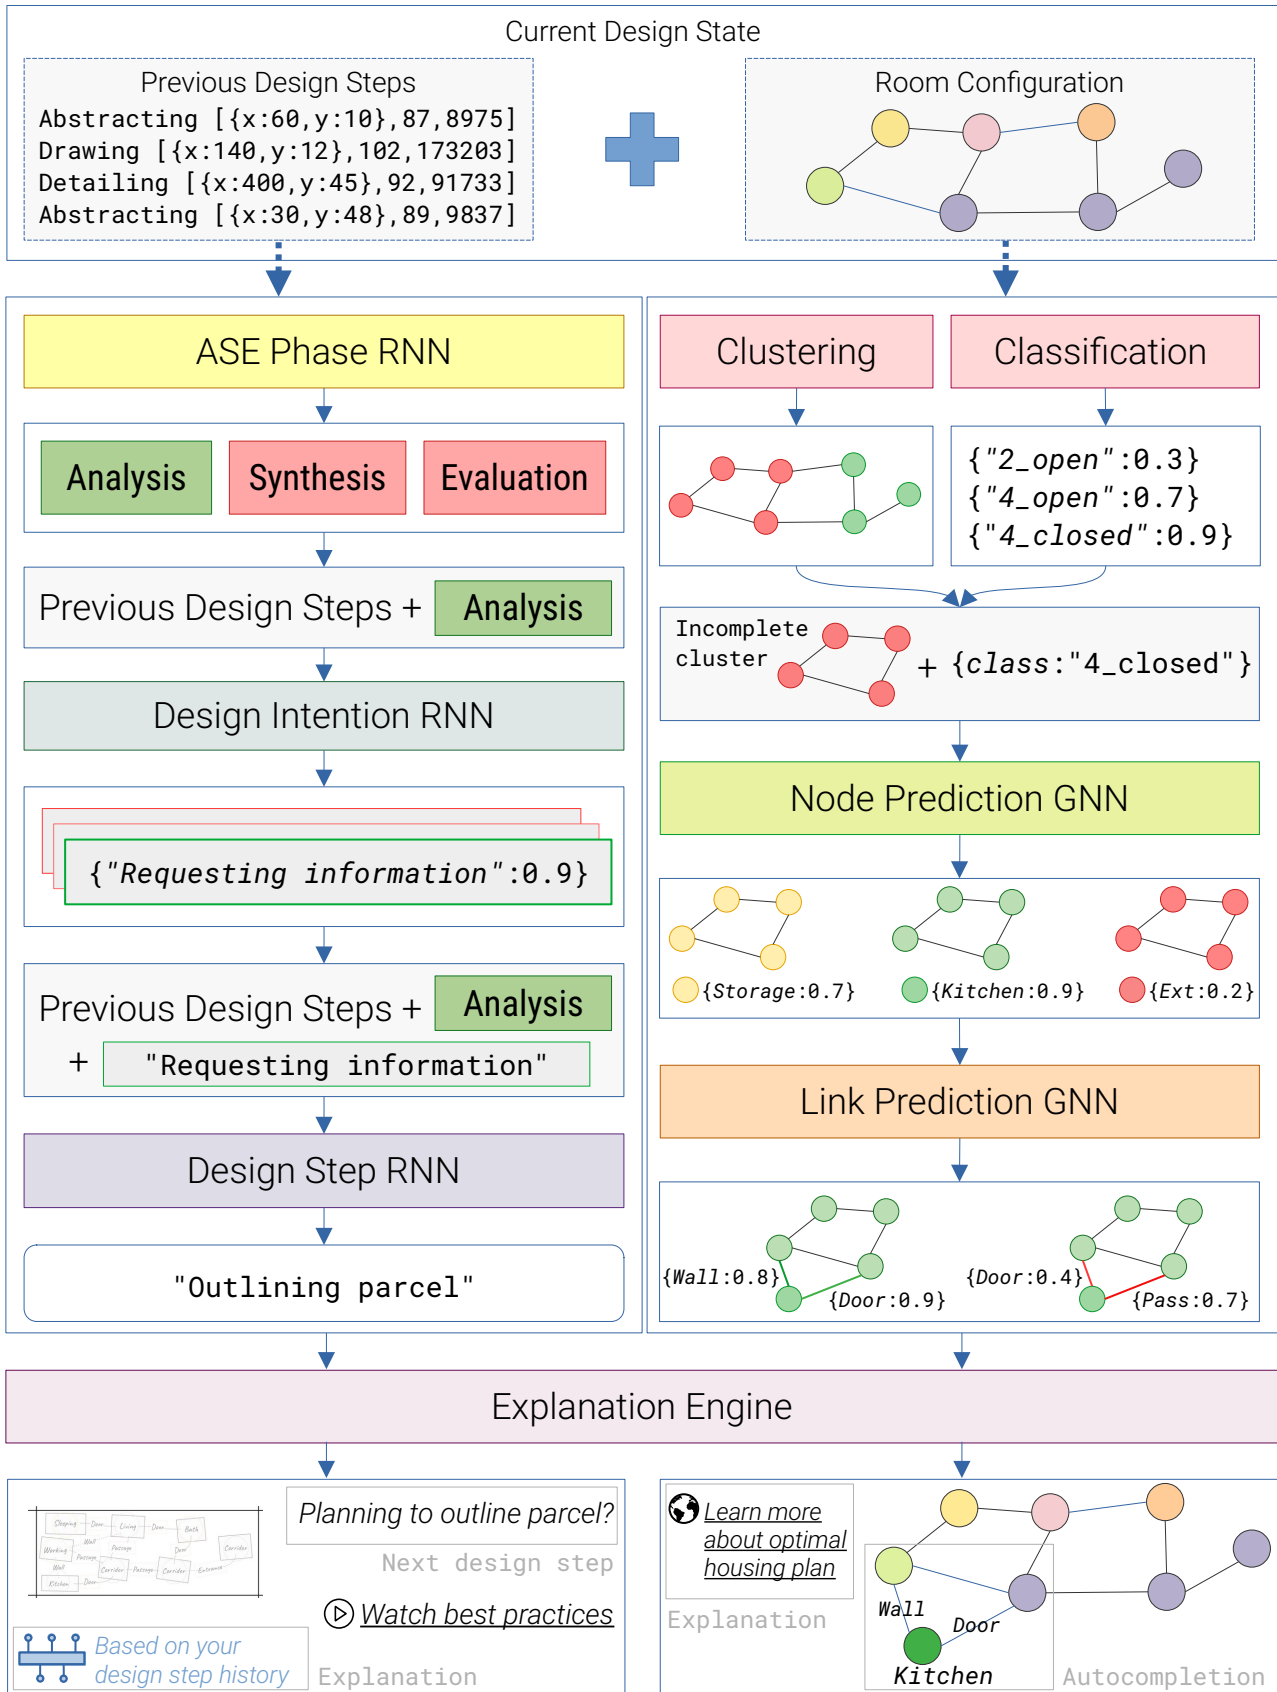


Abbildung 2: KI-Ansätze zur Autovervollständigung von Raumkonfigurationen und Entwurfsschritten.

Die ermittelte Intention wird dann der nächsten Anfrage hinzugefügt, ebenso die Entwurfsschritte und die Entwurfsphase. Mithilfe eines dritten RNNs wird dann diese gesamte Sequenz analysiert um den nächsten Entwurfsschritt vorzuschlagen. Dieser beschreibt die konkrete Aktion des Skizzierens in der frühen Entwurfsphase, bspw. „starting new sketch“, „outlining parcel“ oder „abstracting with bubble diagrams“. Dieser Teilschritt schließt zunächst den ersten Ansatz der Methodologie ab.

### 3.1.2 Ansatz 2: Autovervollständigung der Raumkonfiguration

Im zweiten Ansatz der KI-Methodologie werden Vorschläge zur Komplettierung der aktuellen Raumkonfiguration erarbeitet (s. Abb. 2, rechts). Angefangen wird mit den folgenden parallelen Teilschritten:

- *Clustering*: Hierbei wird die Raumkonfiguration in die Teilkonfigurationen (Cluster) aufgeteilt, bspw. mit dem Verfahren nach Girvan und Newman [11]. Dabei werden sog. problematische bzw. im architektonischen Sinne unvollständige Cluster ermittelt.
- *Klassifikation*: In diesem Teilschritt wird die Wohnbauklasse der Raumkonfiguration, repräsentiert als „Relation Map“ (s. Kap 2), mithilfe eines Convolutional Neural Networks ermittelt. Die Klasse besteht aus der Anzahl der Wohnräume (bspw. 2 oder 3) und der Angabe, ob das Wohnzimmer mit der Küche durch eine Passage verbunden („Wohnküche“) ist oder nicht („open“ oder „closed“).

Die Kombination aus der Wohnbauklasse und den nicht vollständigen Clustern wird dann als Anfrage an ein Graph Neural Network (GNN) benutzt, welches die Räume vorschlagen soll, die für die Verbindungen im Cluster und die Wohnbauklasse typisch sind. GNNs sind ein spezieller Subtyp von neuronalen Netzen, der direkt mit dem Graphen arbeiten kann, anstatt den Umweg über Konvertierung in eine andere Repräsentation (Feature-Vektor, 3D-Matrix) zu nehmen. Alternativ kann hier auch ein Verfahren aus dem Bereich *Fallbasiertes Schließen* (engl: case-based reasoning, CBR) verwendet werden, welches ähnliche Cluster in einer Datenbank durchsucht und die Raumdifferenzen auflistet.

Nachdem die Räume der Autovervollständigung hinzugefügt wurden, werden mit dem ebenfalls GNN-basierten Verfahren *Link Prediction* [12] die Verbindungen zwischen den fehlenden bzw. vorgeschlagenen und den bereits existierenden Räumen im Cluster gesucht. Link Prediction versucht dabei alle möglichen Verbindungen zu prüfen um dann diejenigen mit der höchsten Wahrscheinlichkeit der Autovervollständigung hinzuzufügen. Mit dem kombinierten Vorschlag, bestehend aus neuen Räumen und Verbindungen endet zunächst der zweite Ansatz der Methodologie.

## 3.2 Erklärbarkeit

Für die vorläufigen Ergebnisse beider Ansätze der Methodologie wird dann das XAI-Verfahren angewandt, welches diese Ergebnisse um visuelle und/oder textuelle Komponenten ergänzt, die der Zielgruppe der Anwender gegenüber die vorgeschlagenen Lösungen nachvollziehbar machen sollen. XAI steht für *eXplainable AI* (erklärbare künstliche Intelligenz) und ist ein Forschungsbereich der KI in dem die Methoden zur menschenlesbaren Erklärung von Verhalten von intelligenten Systemen erarbeitet und angewandt werden [13]. Mögliche Ansätze die für die Erklärung von Autovervollständigungen



in Frage kommen können sind die Erklärungsmuster (engl.: explanation patterns) nach Cassens und Kofod-Petersen [14], die bereits im Rahmen der Forschungsprojekte *metis* für die Rechtfertigung, Relevanzanalyse, und den Transparenzbericht zur fallbasierten Suche nach ähnlichen Referenzen angewandt wurden. Ein weiter Ansatz ist das XAI-Framework nach Wang et al. [15], das kontrastive (warum), transfaktische (wie) oder kontrafaktische (was wäre wenn) Erklärungen generiert.

Das endgültige Ergebnis beider Ansätze zur automatischen Vervollständigung von frühen Grundrissen ist dann die Kombination aus den Ergebnissen, die von den KI-Ansätzen erzielt wurden und den dazugehörigen Erklärungen, visualisiert für die Ausgabe in einer Benutzeroberfläche (s. Abb 2, unten).

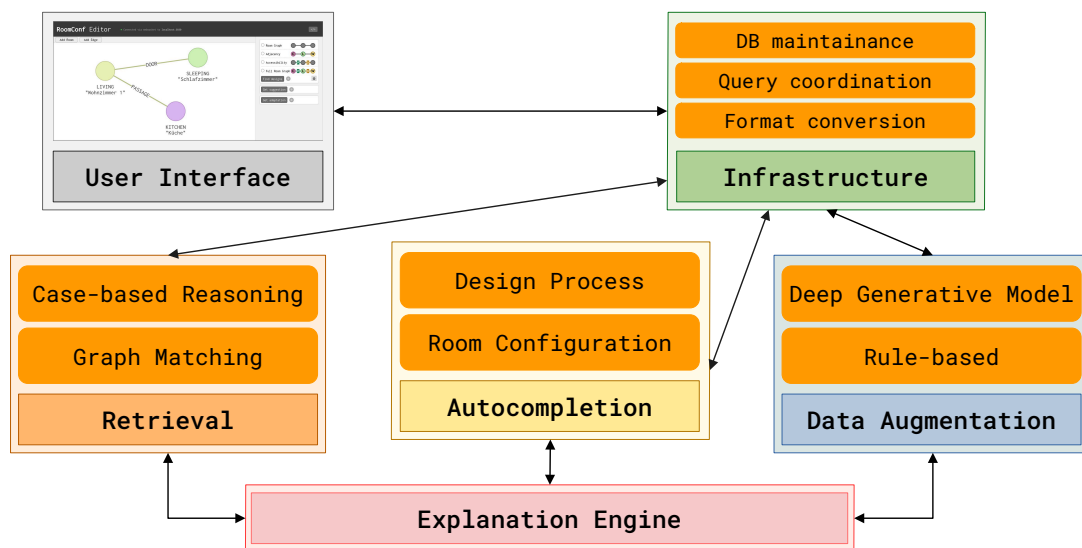


Abbildung 3: Framework *MetisCBR* mit Integration der Autovervollständigung.

## 4 Integration in das Framework & Evaluation

Die Ansätze zur Autovervollständigung werden dann, so wie bereits die XAI-Komponente und die Benutzeroberfläche, in das Framework *MetisCBR* zur Unterstützung der frühen Entwurfsphase in der Architektur integriert. Zum Framework gehören außerdem die bereits erwähnte Retrieval-Komponente zur Suche nach ähnlichen Referenzen sowie die Methoden zur KI-basierten Generierung von architektonisch konsistenten Grundrissdaten zum Training von Deep-Learning-Modellen. Der Grundaufbau des Frameworks setzt auf eine verteilte agentenbasierte Software-Architektur (Multiagentensystem), die während der Forschungsaktivitäten für die Projekte *metis* entwickelt wurde. Die Integration der Ansätze zur Autovervollständigung in *MetisCBR* (s. Abb. 3) erweitert das Framework um eine weitere Methode zur Unterstützung des frühen Entwurfs und macht es zu einem Referenz-Tool der Projekte *metis*, mit dem der Einsatz der KI in der Architektur weiter erforscht und evaluiert werden kann.

Die initialen Evaluationen der Integration der Methodologie bestätigen die Eignung der RNNs für die Erkennung der ASE-Entwurfsphase bzw. GNNs für Link Prediction, beide erreichen Werte von über 90% Richtigkeit. Die Implementierung der Methodologie wird mit einer Gesamtevaluation abgeschlossen.

## Literatur

- [1] I. Goodfellow, J. Pouget-Abadie, M. Mirza u. a., »Generative adversarial nets«, *NeurIPS*, 2014.
- [2] T. Brown, B. Mann, N. Ryder u. a., »Language models are few-shot learners«, *NeurIPS*, 2020.
- [3] V. Eisenstadt, J. Bielski, B. Mete, C. Langenhan, K.-D. Althoff und A. Dengel, »Autocompletion of Floor Plans for the Early Design Phase in Architecture: Foundations, Existing Methods, and Research Outlook«, in *CAADRIA 2022 Proceedings*, 2022, S. 323–332.
- [4] D. Aliakseyeu, »A computer support tool for the early stages of architectural design«, English, Diss., Industrial Engineering und Innovation Sciences, 2003, ISBN: 90-386-1598-1.
- [5] P. Laseau, *Graphic Thinking for Architects and Designers*. Wiley, 2000, ISBN: 9780471352921.
- [6] K. Richter, *Augmenting Designers' Memory: Case-based Reasoning in Architecture*. Logos-Verlag, 2011, ISBN: 9783832527334.
- [7] M. H. Haeusler, A. Butler, N. Gardner, S. Sepasgozar und S. Pan, »Wasted... Again-Or how to understand waste as a data problem and aiming to address the reduction of waste as a computational challenge«, in *CAADRIA 2021 Proceedings*, Bd. 1, 2021, S. 371–380.
- [8] V. Eisenstadt, H. Arora, C. Ziegler u. a., »Exploring optimal ways to represent topological and spatial features of building designs in deep learning methods and applications for architecture«, in *CAADRIA 2021 Proceedings*, Bd. 1, 2021, S. 191–200.
- [9] B. Lawson, *How Designers Think: The Design Process Demystified* (How Designers Think: The Design Process Demystified). Elsevier/Architectural, 2006, ISBN: 9780750660778.
- [10] R. Barelkowski, »Learning design from knowing less. On approaches to architectural design process«, in *Knowing (by) Designing*, 1st. LUCA KU Leuven, 2013, Kap. 8.1, S. 517–526.
- [11] M. Girvan und M. E. Newman, »Community structure in social and biological networks«, *Proceedings of the national academy of sciences*, Jg. 99, Nr. 12, S. 7821–7826, 2002.
- [12] M. Zhang und Y. Chen, »Link prediction based on graph neural networks«, *NeurIPS*, 2018.
- [13] W. Samek, G. Montavon, A. Vedaldi, L. Hansen und K. Müller, *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning* (LNCS). Springer, 2019, ISBN: 978-3-030-28954-6.
- [14] J. Cassens und A. Kofod-Petersen, »Designing Explanation Aware Systems: The Quest for Explanation Patterns.«, in *ExaCt*, 2007, S. 20–27.
- [15] D. Wang, Q. Yang, A. Abdul und B. Y. Lim, »Designing theory-driven user-centric explainable AI«, in *Proceedings of the 2019 CHI conference on human factors in computing systems*, 2019.